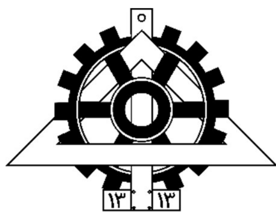




دانشکده مهندسی برق و کامپیوتر

دانشکدگان فنی

دانشگاه تهران

پیشنهاد و فرم حمایت از پایان‌نامه کارشناسی ارشد

نام و نام خانوادگی: امیرحسین عباسی شاهکوه

شماره دانشجویی: ۸۱۰۱۰۲۲۰۱

استاد راهنمای اول: دکتر مهدی کارگهی

تاریخ تصویب:

۱- خلاصه اطلاعات پایان‌نامه

عنوان فارسی	یادگیری بدون نظارت منعطف و ماندگار		
عنوان انگلیسی	Adaptive and Persistent Unsupervised Learning in AI Models: A Flexible Parameter Approach Based on Environmental and Control Conditions		
نوع	بنیادی☐	کاربردی✓	توسعه‌ای☐

۲- اطلاعات استاد راهنما و مشاور

نوع مسئولیت	نام و نام خانوادگی	مرتبه علمی	درصد مشارکت	محل خدمت	امضاء و تاریخ
استاد راهنمای اول (مجری)	مهدی کارگهی	استاد	۱۰۰		
استاد راهنمای دوم (حسب نیاز)		انتخاب نمایید			
استاد مشاور اول		انتخاب نمایید			
استاد مشاور دوم (حسب نیاز)		انتخاب نمایید			

۳- اطلاعات دانشجو

نام و نام خانوادگی	امیرحسین عباسی شاهکوه	**تلفن همراه**	
نوع پذیرش	روزانه	**نشانی پست الکترونیکی**	shahkooh@ut.ac.ir
رشته و گرایش	مهندسی کامپیوتر - گرایش معماری کامپیوتر	**امضاء و تاریخ**	

۱- تعریف مساله، هدف و ضرورت انجام

تعریف مسئله

با رشد فزاینده‌ی قابلیت های هوش مصنوعی و از سوی دیگر نیاز به اینترنت اشیا در راستای انقلاب صنعتی چهارم[۱] ترکیب این دو حوزه در یکدیگر در قالب هوش نهفته[۲] به یک زمینه ی درحال توسعه در کاربردهایی ازجمله شهر هوشمند، دستیارهای صوتی هوشمند و شناسایی فعالیت های هوشمند تبدیل شده است. غالب پژوهش ها در زمینه ی هوش نهفته، مبتنی بر دو رویکرد محاسبات ابری[۳] و محاسبات درلبه[۴] می باشند.[1] در رویکرد محاسبات ابری، دستگاه های لبه[۵] داده ها را از حسگرها جمع آوری می کنند و به فضای ابری ارسال می کنند تا بااستفاده از منابع نامحدود (نسبت به منابع محدود فضای لبه) عملیات آموزش را انجام داده و متغیرهای به‌روزرسانی شده ی آموزشی را از فضای ابری به فضای لبه ارسال کند و مدلِ هوشمند، به‌روزرسانی شود. با این حال، این رویکرد موجب اتکای فضای لبه به فضای ابری برای یادگیری می شو. برخی از مهمترین چالشها عبارتند از :

- **سربار ارتباط فضای لبه و فضای ابری**؛ در بسیاری از کاربردهای هوش نهفته این موضوع به چالش بزرگتری تبدیل می شود چراکه فضای لبه در مناطقی با پوشش ارتباطی بسیار محدود و ناچیز قرار می گیرد.[2]
- **امنیت و حریم شخصی**؛ در رویکرد استفاده از فضای ابری، امنیت داده ها همواره در معرض خطراتی مثل دسترسی غیرمجاز، انتشار غیرمجاز و هک شدن قرار دارد. حتی روش هایی مثل پیش‌پردازش داده ها نیز نمی تواند کاملا امنیت داده را تضمین کند.[2]
- **وابستگی به فضای ابری**؛ معمولا وابستگی به یک سرویس ابری خاص، به یک چالش جدی تبدیل می شود چراکه درصورت توقف خدمات رسانی فضای ابریِ مورد استفاده، انتقال وظایف و تنظیمات موجود به فضای ابری دیگر را دشوار و پرهزینه می کند. به‌علاوه، عدم انعطاف سرویس-دهندگان فضای ابری متناسب با نیازها و هزینه های فضای ابری نیز از چالش ها می باشد.[2]

---

[۱] Industry 4.0
[۲] Embedded Artificial Intelligence
[۳] Cloud Computing
[۴] Edge Computing
[۵] Edge Devices

در رویکرد محاسبات در لبه، تاکید بر افزایش استقلال فضای لبه در محاسبات است که به یک محور پژوهشی در این حوزه تبدیل شده است. مطابق این پژوهش ها، مهم‌ترین چالش رویکردهای مبتنی بر استقلال در یادگیری، **محدودیت منابع** می باشد. این محدودیت در منابع حافظه و محاسباتی و محدودیت زمانی مورد بررسی قرار می‌گیرند. [1]

در کنار رویکرد انتخابی در زمینه ی هوش نهفته، فضای مسئله نیز چالش های خود را به همراه دارد. برای مثال در یادگیری نظارت شده که در آن مدل پیش از عملیات، به اندازه ی لازم تحت آموزش قرار می گیرد، **جمع آوری و برچسب گذاری داده به اندازه ی کافی** از چالش ها خواهد بود. با این حال، در بسیاری از کاربردهای هوش نهفته مانند دوربین های کنترلی، فضای مسئله، ضرورتِ استفاده از یادگیری بدون نظارت را منجر می شود. براساس پژوهش های اخیر، مهمترین چالش های باقی مانده در این فضا عبارتند از :

- **داده های لحظه ای، وابسته و غیریکنواخت**[۶]معمولا بخش قابل توجه‌ای از داده های ورودی را در این مسائل تشکیل می دهد. این موضوع از این لحاظ چالش آفرین است که علاوه بر تنوع ماهیتی داده ها به دلیل تنوع حسگرهای موجود، این داده ها معمولا دچار وابستگی معنایی نیز هستند. به عبارتی، از آنجایی که داده ها به ترتیب زمانی وارد سامانه می شوند، نسبت به شرایط زمانی و مکانی وابستگی هایی دارند. برای مثال، داده های حسگرهای دما و رطوبت در فصل پاییز که معمولا هوا بارانی است، به مقادیر مشخصی همگرا می شود.[1]
- **فراموشی فاجعه بار**[۷]پدیده ایست که درپی آن، متغیرهای یادگیریِ مدلِ هوشمند پایدار، تحتِ تاثیر داده های تازه، بر آنها متمرکز می شود؛ به حدی که یادگیری های قبلی خود را فراموش می کند. برای مثال در یک سامانه ی پیش بینی آب و هوا، در فصل زمستان ممکن است مدل تحت تاثیر این پدیده پیش بینی های خود را به ازای داده های آب و هوا در تابستان فراموش کند و با فرارسیدن دوباره ی فصل تابستان در سال آینده، سامانه رفتارهای اشتباه خود را تکرار کند.[1]

[۶] Non-iid Data

[۷]Catastrophic Forgetting

اهداف

با درنظر گرفتن چالش های ذکر شده، مفروض بر اتخاذ رویکرد **محاسبات لبه** در فضای **یادگیری بدون نظارت** هدف‌گذاری پژوهش، معرفی یک مدل هوشمند با ویژگی های زیر می باشد :

- **بدون نظارت** عملیات یادگیری را انجام دهد. با توجه به تنوع داده ها و کمبود داده های برچسب- گذاری شده، پیش از عملیات و استنتاج، آموزشی وجود ندارد و یا بسیار محدود است. بنابراین، مدل براساس فهم خود از داده های ورودی باید آنها را خوشه بندی کند.
- **ماندگار** باشد. با توجه به چالش فراموشی فاجعه‌بار، مدل باید قادر به حفظ آموزش های قبلی خود باشد تا بتواند در مدت زمان طولانی، عملیات را به صورت پایدار انجام دهد.
- **منعطف** باشد. با توجه به چالش محدودیت منابع در رویکرد انتخابی، عملیات یادگیری و استنتاج در هرلحظه باید براساس توان محاسباتی موجود، محدودیت زمانی و منابع ادامه یابد.

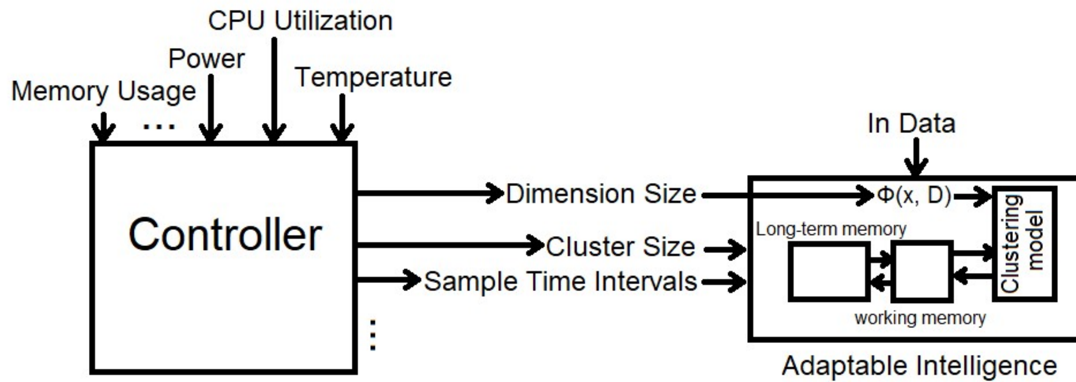
مطابق شکل ۱، معماری پیشنهادی این پژوهش براساس اهداف تعیین شده از چند جهت قابل بررسی می‌باشد:

- به منظور پیاده سازی یادگیری بدون نظارت به ازای داده های ورودی متنوع و پرشمار و همچنین سهولت در محاسبات، از محاسبات فرابُعدی[۸]استفاده شده است. دراین روش، داده های ورودی به فرابُردارهایی[۹]نگاشت می شوند که بردارهایی عظیم (هزاران بُعد) و بیان‌گر ویژگی های مشخص از داده ها می‌باشد که حاصل تجمیع داده ها در یک دوره ی مشخص از نمونه‌برداری است. اگرچه نگاشت داده‌ها به این فرابردارها سبب کاهش دقت می شود اما به‌علت محدودیت در مقادیر استفاده شده، در طراحی و پیاده‌سازی و همچنین استفاده از حافظه و محاسبات، سهولت بیشتری دارند.[3]
- به منظور طراحی یک هوش ماندگار با حداقل فراموشی در یادگیری طولانی‌مدت، یک معماری حافظه ی سلسله مراتبی پیشنهاد شده است. به این ترتیب که حافظه به دو بخش حافظه‌ی کاری و حافظه‌ی تثبیتی تقسیم شده است. حافظه‌ی کاری، برای محاسبات استنتاج و یادگیری مثل استخراج خوشه ها[۱۰]استفاده می شود. هم‌زمان، حافظه ی تثبیتی برای عملیات تثبیت یادگیری مثل ذخیره سازی خوشه های پرتکرار و ادغام خوشه های مشابه به کار می رود.

[۸]Hyperdimensional computing
[۹]Hyper-vector
[۱۰]Cluster

- برای انعطاف در مصرف منابع، از یک کنترل کننده استفاده می شود. بخش کنترل کننده بر متغیرهای تعریف کننده ی شرایط فیزیکی مثل دما و کنترلی مثل وضعیت حافظه، نظارت می کند و براساس این معیارها، سیاست های ازپیش مشخص را اتخاذ می کند. محاسبات در هر لحظه، براساس سیاست های اتخاذ شده در کنترل کننده ادامه خواهد یافت که به معنای انعطافِ محاسبات در شرایط متفاوت می‌باشد. همچنین، باید موارد زیر را درنظر داشت:
  - با تغییر طول فرابردار، معنای داده ی تناظریافته تغییر نمی کند؛ بلکه فقط دقت آن کاهش می‌یابد. علاوه بر آن که با استفاده از روش های توزیع معنایی مثل تبدیل فضای تک بُعدی به چندبعدی می توان فرابردار را به گونه ای نگاشت کرد که با کاهش طول آن، فقط بخشی از نگاشت مربوط به هر داده پنهان شود، باتوجه به اینکه ماهیت داده های ورودی مستقل از یکدیگر نیستند، با استفاده از معیار همبستگی آماری بین داده ها می توان نتیجه گرفت که کاهش طول فرابردار به از دست دادن معنای داده منجر نخواهد شد.
  - کاهش تعداد خوشه های مجاز به‌علت محدودیت حافظه، منجر به فراموشی نمی‌شود؛ چراکه مدیریت حافظه، نگهداری داده ها را بر اساس اولویت های تعیین شده انجام می دهد. بنابراین، داده های مربوط به یادگیری مانند اطلاعات خوشه ها اولویت بیشتری در حفظ خواهند داشت. ضمن این‌که با رویکرد نگرش فازی به مسئله ی تثبیت، می‌توان حافظه ی تثبیتی را به صورت چندبخشی درنظر گرفت که هربخش از آن، درجه اهمیت متفاوتی (مثلا به ازای نرخ اصابت)[۱] داشته باشد.

[۱] Hit Rate



شکل ۱ –معماری یادگیری بدون‌نظارت منعطف و ماندگار – در این معماری، کنترل کننده متغیرهای فیزیکی و کنترلی را در هر دوره ی زمانی درنظر می گیرد و براساس وضعیت موجود، سیاست لازم را اتخاذ می کند. این سیاست، بر تنظیمات محاسبات استنتاجی و یادگیری مانند اندازه ی فرابردارها تاثیر خواهد داشت. در بخش محاسبات نیز، از حافظه ی کاری برای محاسبات و حافظه ی تثبیتی برای حفظ یادگیری استفاده می شود. داده های ورودی نیز به فضای فرابُعدی نگاشت می شوند.

الگوریتم ۱ : کنترل کننده‌ی محاسبات مدل هوشمند

Control Parameters Inputs : $Params_{\pi} = \{CPU_{Utilization}.\ Memory_{Usage} \dots\}$

Physical Parameters Inputs : $Params_{\Delta} = \{Temperature.\ Power \dots\}$

Configuration Inputs : Control period T_c

Output : Computation Parameters $Params_C^{T_i}$ for Time Step T_i

```
Every {T_i ∈ Z^+ | T_i mod T_c = T_Start} TimeStep do
    Constraints ← PolicyConstraints (Params_π ∪ Params_Δ)
    Params_C^{T_i} ← argmax_{Params_c ∈ Constraints} PreEvaluation_{Accuracy...}(Params_c)
    return Params_C^{T_i}
end
```

الگوریتم ۲ : استنتاج و یادگیری مدل هوشمند تحت متغیرهای کنترل کننده

Computation Parameters Inputs : $Params_C^{T_i} = \{\tau_\Delta .\ \Delta .\ Size_{Cluster} .\ Size_{Dimension} \dots \}$

Data Inputs : input data x from sensors

Output : set of clusters μ

1 **if** $\tau_i - \tau_{i-1} \geq \tau_\Delta$ **do**
2 $\overrightarrow{Sample_\iota} \leftarrow \varphi(x \mid Params_C^{T_i})$
3 $\vec{\gamma}^* \leftarrow \underset{\gamma \in Memory_{working} \cup Memory_{LongTerm}}{argmin} \left\| \vec{\gamma} - \overrightarrow{Sample_\iota} \right\|$
4 **if** $\left\| \vec{\gamma}^* - \overrightarrow{Sample_\iota} \right\| > \Delta$ **then** add $\overrightarrow{Sample_\iota}$ into Working Memory
5 **else** $Increase\ \overrightarrow{H\iota t(Index(\vec{\gamma}^*))}$
6 **go to line 8**
7 **else**
8 $Memory_{LongTerm} \leftarrow Memory_{LongTerm} \cup \{\gamma \in Memory_{working} \mid Hit(Index(\gamma)) \geq \eta\}$
9 $Memory_{working} \leftarrow \{\gamma \in Memory_{working} \mid Hit(Index(\gamma)) < \eta\}$
10 $SortedByHit \leftarrow \{\gamma \in Memory_{working} \mid \forall \alpha . \beta \in \mathbb{R}.\ \alpha \leq \beta \Rightarrow Hit(Index(\gamma_\alpha)) \geq Hit\left(Index(\gamma_\beta)\right)\}$
11 $Memory_{working} \leftarrow \{\gamma_i \in SortedByHit \mid 1 \leq i \leq \lambda_{working}\}$
12 $SortedByHit \leftarrow \{\gamma \in Memory_{LongTerm} \mid \forall \alpha . \beta \in \mathbb{R}.\ \alpha \leq \beta \Rightarrow Hit(Index(\gamma_\alpha)) \geq Hit\left(Index(\gamma_\beta)\right)\}$
13 $Memory_{LongTerm} \leftarrow \{\gamma_i \in SortedByHit \mid 1 \leq i \leq \lambda_{LongTerm}\}$
14 **end**
15 **return** $\mu = Memory_{working} \cup Memory_{LongTerm}$

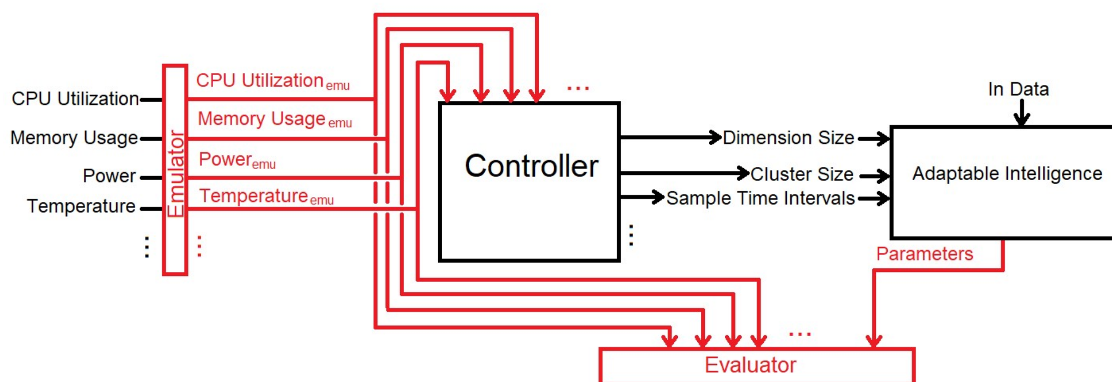
مطابق معماری ارائه شده، متغیرهای مورد پژوهش عبارتند از حداکثر اندازه ی فرابردار، تعداد مجاز برای خوشه ها، دوره ی نمونه برداری، دوره ی کنترلی، متغیرهای فیزیکی تحت نظارت، متغیرهای کنترلی تحت نظارت، اندازه ی حافظه های کاری و تثبیتی و ضریب شباهت خوشه ها. برای مثال، متغیر اندازه ی فرابردار که طول فرابردار تناظریافته ی داده ی ورودی را تعیین می کند، مستقیما با زمان و همچنین پیچیدگی محاسبات دارارتباط است. همچنین براثر محدودیت های حافظه ای ناشی از عملیاتهایی مثل به‌روزرسانی، متغیرهایی مانند تعداد خوشه های مجاز نیز دچار تغییر می شوند که بر میزان مصرف حافظه اثرگذار است.

ضرورت انجام

- **کنترل مصرف منابع محاسباتی و حافظه و محدودیت های زمانی :** در رویکرد یادگیری و استنتاج مستقل، توجه به محدودیت ها براساس شرایط فیزیکی و کنترلی از نکات ضروری می باشد. در همین راستا، پیشنهاداتی مطرح شده است که یکی از آنها، روش محاسبات منعطف و رصد دوره‌ای شرایط و ادامه‌ی عملیات بر اساس محدودیت های موجود می باشد.
- **یادگیری ماندگار :** با توجه به استفاده ی طولانی‌مدت از خدمات هوشمند مستقل در کاربردهایی مثل کشاورزی هوشمند و همچنین لزومِ به حداقل رساندن نیاز به راه‌اندازی مجدد و به‌روزرسانی، ماندگاری در یادگیری به‌منظور پیشگیری از وقوع فراموشی ضرورت دارد.

۲- روش و فنون اجرایی

باتوجه به اینکه در این پژوهش، ارزیابی معیارهای دقت، سرعت و مصرف در شرایط متفاوت مورد توجه می باشد، این آزمایشات در فازهای متفاوت صورت می گیرد که در هر فاز، رفتار مدل و همچنین نتایج خروجی تحت شرایط تحمیلیِ آزمایش ارزیابی می شود. مطابق شکل ۲ در هر فاز، با استفاده از ابزار سخت‌افزاری و شبیه‌ساز نرم افزاری، شرایط آزمایش به مدل تحمیل می شود و سپس رفتار مدل در هرکدام از این شرایط به‌صورت جداگانه ارزیابی خواهد شد.



شکل ۲ –معماری ارزیابی رفتار مدل تحت شرایط مختلف.

الگوریتم ۳ : ارزیابی رفتار مدل با استفاده از شبیه‌ساز

Control Parameters Inputs : $Params_{\pi} = \{CPU_{Utilization}.\ Memory_{Usage} \dots\}$

Physical Parameters Inputs : $Params_{\Delta} = \{Temperature.\ Power \dots\}$

Evaluation Inputs : Test data x_t

Configuration Inputs : Control period T_c

Output : Evaluation results $\overrightarrow{Evaluation}$ over input test data x_t and clusters set μ

$Initialize\ (\overrightarrow{Evaluation})$
Every $\left\{T_i \in \mathbb{Z}^{+} \,\middle|\, T_i \bmod T_c = T_{Start}\right\} TimeStep$ **do**
  $Params'_{\pi}\ .\ Params'_{\Delta} \leftarrow Emulation(Params_{\pi} \cup Params_{\Delta})$
  $Params_C^{T_i} \leftarrow ControlParams(Params'_{\pi} \cup Params'_{\Delta})$
  $\mu \leftarrow Computations\ (x_t \mid Params_C^{T_i})$
  $\overrightarrow{Evaluation}_{Params_C^{T_i}} \leftarrow \overrightarrow{Evaluation}_{Params_C^{T_i}} \otimes Evaluation_{Accuracy\dots}(x_t.\mu)$
end
return $\overrightarrow{Evaluation}$

به‌همین منظور، مواد لازم برای انجام این پژوهش عبارتند از :

الف) مجموعه داده ها : مجموعه داده[12]های مورد استفاده در این پژوهش، از میان مجموعه داده های استاندارد در کاربردهای متفاوت خواهد بود. برای مثال، برای شبیه سازی داده های دریافتی از دوربین ها، از مجموعه داده ی CIFAR100 استفاده می شود و از مجموعه داده ی MHEALTH که مرتبط با سلامت جسمی است، برای شبیه سازی داده های دریافتی از حسگرهای فیزیکی استفاده می‌شود. هم‌چنین برای غنی‌سازی داده های ورودی و نزدیک‌تر کردن شرایطِ آزمایش به واقعیت، از روش های داده‌افزونی مثل توزیع نویز و یا دوران تصاویر ورودی نیز استفاده می شود.

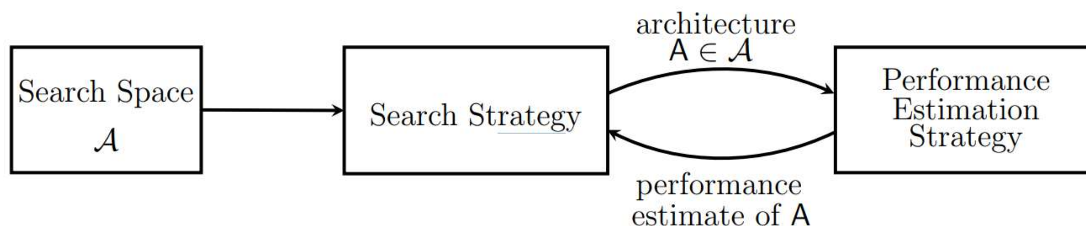
ب) سخت‌افزار : باتوجه به امکانات موجود، معماری پیشنهادیِ پژوهش در ۳ دسته از پردازنده ها با ویژگی‌های متفاوت، مورد ارزیابی قرار خواهد گرفت. این دسته ها به شرحِ یک پردازنده با قابلیت های حداقلی (مثل RPi Zero 2 W)، متوسط (مثل RPi 4B) و حداکثری (مثل Jetson TX2) می‌باشند. سایر ملزوماتِ آزمایش نیز براساس نیازِ حین آزمایش و هم‌چنین امکانات آزمایشگاه انتخاب خواهند شد و در گزارش کار ثبت خواهند شد.

[12]Dataset

۳- پیشینه پژوهش

باتوجه به محدودیت منابع و پویایی شرایط فیزیکی در اغلب کاربردهای محاسبات در فضای لبه، طراحی مدل‌های هوشمند با قابلیت انعطاف و یا سازگاری با حداقل امکانات از اهداف بسیاری از پژوهش های سال-های اخیر بوده است.

اساس بسیاری از این پژوهش ها، روش جستجوی معماری عصبی[۱۳] است. دراین روش مطابق شکل ۳، ابتدا فضای جستجو براساس محدودیت ها و اهداف جستجو تعیین می شود. سپس سیاست‌گذاریِ جستجو به هدف دستیابی به بهترین پاسخ های ممکن با توجه به فضای مسئله و همچنین هدفگذاری ها تعیین می شوند. برهمین اساس، براساس روش هایی مثل الگوریتم ژنتیک، پاسخ هایی تولید می شوند که پس از چند مرحله ارزیابی نهایتا پیشنهاد می شوند.[4]



شکل ۳ –شکل جستجوی معماری عصبی[۱۴]

باید توجه داشت که این روش، کاملا ایستا انجام می شود و در زمان اجرا هیچ انعطاف عملکردی وجود ندارد. به‌عبارتی، این انطباق‌پذیری صرفا در زمان جستجو انجام می شود. [4]

برهمین اساس، ایده ی استنتاج براساس شرایط در زمان اجرا با رویکرد انعطاف در زمان استنتاج، معرفی شده است که در آن، سامانه ای در کاربرد بینایی ماشین با استفاده از مدل های CNN، متناسب با شرایط محیطی و در لحظه، تصمیم می گیرد که از کدام مدل CNN از مدل های موجود استفاده کند. این روش نیز برای مواردی مناسب می باشد که فاز یادگیری جدا می باشد. به این شکل که در فاز یادگیری، براساس یک مدل CNN پایه، طی یک الگوریتم یادگیری ژنتیک جمعیت هایی از آن براساس شرایط تعریف شده تشکیل می شود. این شرایط درواقع وزن هایی را به معیارهایی مثل دقت و مصرف توان هر مدل CNN می

[۱۳] Neural Architecture Search (NAS)

[۱۴] Elsken, Thomas, Jan Hendrik Metzen, and Frank Hutter. "Neural architecture search: A survey." *Journal of Machine Learning Research* 20.55 (2019): 1-21.

دهد. درنهایت به ازای هر شرایط، مجموعه ای از CNN ها را خواهیم داشت که براساس شرایط تعریف شده، محدودیت ها را رعایت می کند و از میان آنها، مدل هایی را برمی گزینیم که بیشترین اشتراک‌پذیری با یکدیگر را دارند. این کار باعث استفاده از اشتراک لایه ها و متغیرهای مدل برای اشتراک بیشتر حافظه و درنهایت کاهش مصرف حافظه می شود.[2] اگرچه این رویکرد، مشکل انطباق درزمان اجرا را ندارد اما همچنان یک مدل پویا نیست.

معماری استنتاج سریع بااستفاده از خروج به‌موقع، با نهفتن خروجی هایی به ازای هر لایه، امکان اتمام فرایند استنتاج در هر لایه را فراهم کرده است. با درنظر گرفتن مدل چندلایه ای که در آن با پیشرفت در مسیر لایه ها دقت استنتاج نسبت به محاسبات در لایه های قبلی افزایش خواهد یافت، بااستفاده از تعداد مشخص از لایه های ابتدایی مدل، به دقت کافی در استنتاج خواهیم رسید. تعداد لایه های ابتدایی بااستفاده از متغیر اطمینان مشخص می شود که دراثر مصالحه بین متغیرهای دقت و پیچیدگی محاسباتی تعیین خواهد شد. [5]

ازجمله دیگر روش های پویا که بسیار مورداستفاده بوده است، انعطاف در متغیرهای تعداد لایه ها و وزن ها، تعداد عملیات ضرب و تجمیع[15] و مصرف حافظه براساس محدودیتهاست. از طرفی امکان استفاده ی دوباره از محاسبات[16] به شرط اشتراک وزنها و لایه ها، مصرف حافظه را در این کاربرد کاهش می دهد. درنهایت، محاسبات بیشتر، می تواند دقت استنتاج را افزایش دهد اما این تصمیم تنها به ازای تاخیر بیشتر در استنتاج اتخاذ خواهد شد. [6]

همچنین در کاربرد بینایی، مدل شبکه ی عصبی شناور نیز معرفی شده است که از یک گراف محاسباتی استفاده می کند. به این صورت که زیرمجموعه های مشخص شده ای از این گراف، متناظر با یک مدل CNN می باشد و در زمان اجرا تصمیم گیری می شود که کدامیک از این زیرمجموعه ها استفاده شود. این انتخاب براساس تخمین پیچیدگی محاسباتی براساس نرخ عملیات ممیزشناور[17] می باشد. [7]

[15] Multiply-Accumulate (MAC)
[16] Reuse of components
[17] FLOPs

منبع شناسی:

[1] Yu, Xiaofan, et al. "Lifelong Intelligence Beyond the Edge using Hyperdimensional Computing." arXiv preprint arXiv:2403.04759 (2024).

[2] Minakova, Svetlana, et al. "Scenario based run-time switching for adaptive CNN-based applications at the edge." ACM Transactions on Embedded Computing Systems (TECS) 21.2 (2022): 1-33.

[3] Kanerva, Pentti. "Hyperdimensional computing: An introduction to computing in distributed representation with high-dimensional random vectors." Cognitive computation 1 (2009): 139-159.

[4] Weiwen Jiang and Xinyi Zhang. 2019. Accuracy vs. efficiency: Achieving both through fpga-implementation aware neural architecture search. In Proceedings of the 56th Annual Design Automation Conference 2019. 1–6.

[5] Teerapittayanon, Surat, Bradley McDanel, and Hsiang-Tsung Kung. "Branchynet: Fast inference via early exiting from deep neural networks." 2016 23rd international conference on pattern recognition (ICPR). IEEE, 2016.

[6] Sun, Wenhao, et al. "SteppingNet: A Stepping Neural Network with Incremental Accuracy Enhancement." 2023 Design, Automation & Test in Europe Conference & Exhibition (DATE). IEEE, 2023.

[7] Yu, Jiahui, et al. "Slimmable neural networks." arXiv preprint arXiv:1812.08928 (2018).

شماره:
تاریخ:

معاون محترم آموزشی و تحصیلات تکمیلی پردیس دانشکده‌های فنی

با سلام و احترام،

فرم پیشنهاد و حمایت از پایان‌نامه جناب آقای -------- **با عنوان**: --------- به راهنمایی سرکار خانم دکتر: ******* که در راستای برنامه جامع تحقیقات ایشان با عنوان: ________________________________ در تاریخ ____________ در شورای پژوهشی و تحصیلات تکمیلی دانشکده مهندسی برق و کامپیوتر به تصویب رسید خواهشمند است، دستور فرمائید اقدامات لازم انجام شود.

معاون پژوهشی و تحصیلات تکمیلی دانشکده مهندسی برق و کامپیوتر

امضاء:

تاریخ:

شماره:
تاریخ:

معاون محترم پژوهشی پردیس دانشکده‌های فنی

با سلام و احترام،

به پیوست، فرم پیشنهاد و حمایت از **پایان نامه** تحصیلات تکمیلی به همراه مشخصات آن، که به تصویب شورای پژوهشی تحصیلات تکمیلی دانشکده‌ی مهندسی برق و کامپیوتر رسیده است جهت دستور به اقدام مقتضی تقدیم می‌شود.

معاون آموزشی و تحصیلات تکمیلی پردیس دانشکده های فنی

امضاء:

تاریخ: